

IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

#3

APPLICANT(S): JOSEF BAUER ET AL. DOCKET NO P00,1701
SERIAL NO.: 09/642,452 ART UNIT: Not Assigned
FILED: AUGUST 18, 2000 EXAMINER: Not Assigned
TITLE: "METHOD AND ARRANGEMENT FOR SPEECH RECOGNITION"

Assistant Commissioner for Patents,
Washington, D.C. 20231

SUBMISSION OF CERTIFIED COPY OF PRIORITY DOCUMENT

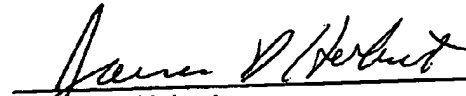
Enclosed is a certified copy of the priority document for which priority is claimed for the above-identified application under 35 U.S.C. §119. Specifically, the document enclosed is:

199 39 102.5

Germany

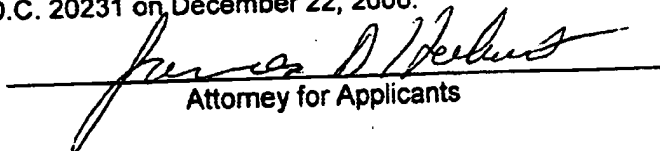
18 August 1999

Respectfully submitted,


(Reg. No. 24,149)
James D. Hobart
Schiff Hardin & Waite
Patent Department
6600 Sears Tower
233 South Wacker Drive
Chicago, Illinois 60606-6473
(312) 258-5779
Attorneys for Applicant

CERTIFICATE OF MAILING

I hereby certify that this correspondence is being deposited with the United States Postal Service as First Class Mail in an envelope addressed to: Assistant Commissioner for Patents, Washington, D.C. 20231 on December 22, 2000.


Attorney for Applicants

#3



**Prioritätsbescheinigung über die Einreichung
einer Patentanmeldung**

Aktenzeichen: 199 39 102.5

**CERTIFIED COPY OF
PRIORITY DOCUMENT**

Anmeldetag: 18. August 1999

Anmelder/Inhaber: Siemens AG, München/DE

Bezeichnung: Verfahren und Anordnung zum Erkennen von
Sprache

IPC: G 10 L 15/00

**Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ur-
sprünglichen Unterlagen dieser Patentanmeldung.**

München, den 6. September 2000
Deutsches Patent- und Markenamt
Der Präsident
Im Auftrag

 Hoß

Beschreibung**Verfahren und Anordnung zum Erkennen von Sprache**

- 5 Die vorliegende Erfindung betrifft ein Verfahren und eine Anordnung zum Erkennen von Sprache.

Verfahren zum automatischen Erkennen von Sprache werden in Spracherkennungssystemen eingesetzt. Anwendungen von Spracherkennungssystemen sind z.B. Diktiersysteme oder automatisch arbeitende Telefonvermittlungen.

- Bei bisher bekannten Verfahren zum automatischen Erkennen von Sprache werden durch Nebengeräusche häufig Erkennungsfehler verursacht. Bei diesen Nebengeräuschen unterscheidet man zwei Arten, nämlich die Sprache eines weiteren Sprechers, die zwar meistens korrekt erkannt wird, aber dem Sprachsignal des eigentlichen Sprechers nicht zugeordnet werden sollte, und ein kein Sprachsignal darstellendes Nebengeräusch, wie z.B. Atemgeräusche, das fälschlicherweise als Sprache erkannt wird.

Die Nebengeräusche stellen eine erhebliche Fehlerquelle bei der automatischen Erkennung von Sprache dar.

- 25 Zur Vermeidung derartiger Fehler werden Spracherkennungssysteme auf die Sprechweise der einzelnen Sprecher trainiert, so daß das Spracherkennungssystem feststellen kann, ob das akustische Signal vom Sprecher stammt oder ein Nebengeräusch ist. Spracherkennungssysteme mit häufig wechselnden Sprechern können nicht auf jeden einzelnen Sprecher trainiert werden. So ist es unmöglich, bei einem in eine Telefonanlage integrierten Spracherkennungssystem mit jedem Anrufer eine mehrere Minuten dauernde Trainingsphase durchzuführen, bevor er seine Nachricht sprechen kann, die oftmals nur Bruchteile einer Minute dauert.

Demnach ist es die Aufgabe der vorliegenden Erfindung, ein Erkennen von Sprache zu ermöglichen, wobei durch Nebengeräusche erzeugte Erkennungsfehler verringert werden.

- 5 Diese Aufgabe wird gemäß den Merkmalen der unabhängigen Patentansprüche gelöst. Weiterbildungen der Erfindung ergeben sich auch aus den abhängigen Ansprüchen.

10 Zur Lösung der Erfindung wird ein Verfahren zum Erkennen von Sprache angegeben, bei dem anhand von Wortgrenzen Wörter und Pausen in der Sprache bestimmt werden. Es wird eine mittlere Ruhelautstärke (Si-Level) während der Pausen ermittelt. Auch wird eine mittlere Wortlautstärke (Wo-Level) für die Wörter ermittelt. Weiterhin wird eine Differenz (Δ) zwischen der
15 mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) bestimmt. Sprache wird erkannt, falls die Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) größer als ein vorbestimmter Schwellwert (S) ist. Ansonsten wird keine
20 Erkennung der Sprache in diesem Bereich durchgeführt.

Die Differenz Δ bildet einen Lautstärkenabstand zwischen den gesprochenen Wörtern und den Geräuschen in den Pausen. Ist der Lautstärkenabstand eines erkannten Wortes zu gering, wird
25 es als nicht korrekt erkanntes Wort bewertet. Es wird somit festgestellt, ob ein Wort einen vorbestimmten Lautstärkenabstand zum übrigen Geräuschpegel besitzt. Hierbei wird der Umstand ausgenutzt, daß Nebengeräusche, die bei herkömmlichen Verfahren zum automatischen Erkennen von Sprache häufig zu
30 fehlerhaften Erkennungen führen, leiser als die vom Sprecher gesprochenen Wörter sind. Diese Nebengeräusche können mit der Erfindung einfach ausgefiltert werden, unabhängig davon, ob sie Wörter enthalten oder Geräusche sind, die kein Sprachsignal darstellen.

35

Das erfindungsgemäße Verfahren kann zudem sehr einfach realisiert werden, da lediglich die mittlere Lautstärke über Teile

des zu analysierenden Sprachsignalabschnittes bestimmt werden muß. Als Lautstärke im Sinne der Erfindung wird jede physikalische Größe verstanden, die etwa proportional zur physikalischen Lautstärke ist, die in Dezibel gemessen wird. Hierzu
5 proportionale Größen sind die Energie des akustischen Signals bzw. eines korrespondierenden elektrischen Signals und insbesondere deren elektrische Größen, wie z.B. die Spannung oder der Strom.

10 Insbesondere ist es bei der Erkennung von Sprache wesentlich, daß die richtigen Äußerungen des richtigen Sprechers erkannt werden. Dies ist insoweit problematisch, als ein Umgebungsgeräusch, in dem deutlich Sprachbestandteile enthalten sind, von einem System zur Erkennung von Sprache derart aufgefaßt
15 werden können, als stammten sie von dem Sprecher von dem die tatsächlich zu erkennende Sprache kommt. Um eine Vermischung zu verhindern, wird hiermit ein Verfahren zur Unterscheidung der richtigen von der falschen gesprochenen Sprache angegeben. Insbesondere ist der Pegel des Sprechers, dessen Sprache
20 zu erkennen ist, zumeist deutlich höher, als Sprache von dem Störgeräusch, das zumeist aus dem Hintergrund kommt. Somit kann anhand des Lautstärkepegels des Sprechers, dessen Sprache erkannt werden soll, diese von dem Hintergrundgeräusch unterschieden werden.

25

Ferner wird zur Lösung der Aufgabe eine Anordnung zum Erkennen von Sprache angegeben, die eine Prozessoreinheit aufweist, die derart eingerichtet ist, daß

- 30 a) anhand von Wortgrenzen Wörter und Pausen in der Sprache bestimmbar sind;
- b) eine mittlere Ruhelautstärke (Si-Level) während der Pausen ermittelbar ist;
- c) eine mittlere Wortlautstärke (Wo-Level) für die Wörter ermittelbar ist;
- 35 d) eine Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) bestimmbar ist;

- e) Sprache erkannt wird, falls die Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) größer als ein vorbestimmter Schwellwert (S) ist;
- 5 f) ansonsten keine Erkennung der Sprache durchgeführt wird.

Diese Anordnung ist insbesondere geeignet zur Durchführung des erfindungsgemäßen Verfahrens oder einer seiner vorstehend
10 erläuterten Weiterbildungen.

Die Erfindung wird im folgenden unter Bezugnahme auf die zugehörigen Zeichnungen beispielhaft näher erläutert.

15 In den Zeichnungen zeigen

Fig.1 schematisch ein Verfahren zur Erkennung von Sprache in einem Flußdiagramm;

20 Fig.2 ein Diagramm, das einen Teil eines Signalabschnittes darstellt;

Fig.3 schematisch eine Telekommunikations-Anlage, die nach dem erfindungsgemäßen Verfahren arbeitet, in einem
25 Blockschaltbild.

In Fig.1 ist ein Verfahren zum automatischen Erkennen von Sprache schematisch dargestellt. Dieses Verfahren wird in der Praxis durch ein Computerprogramm realisiert, das auf einem
30 Computer oder eineressoreinheit arbeitet, die einen Eingang für ein Sprachsignal aufweist.

Das Verfahren bzw. das entsprechende Programm wird im Schritt S1 gestartet. Im folgenden Schritt S2 wird ein Wort eines
35 Sprachsignals S analysiert. Diese Analyse erfolgt in an sich bekannter Weise, wobei das akustische Sprachsignal, das üblicherweise als in ein elektrisches Signal gewandeltes Signal

vorliegt, in Wörter und Pausen segmentiert wird und die Wörter in Text gewandelt werden. Das Segmentieren des Signalabschnittes erfolgt z.B. nach dem Viterbi-Alignment-Verfahren.

5 In Fig.2 ist ein Diagramm dargestellt, das in einem Koordinatensystem einen Teil eines Signalabschnittes S zeigt. In diesem Koordinatensystem ist auf der Abszisse die Zeit t und auf der Ordinate die Lautstärke aufgetragen. Die Lautstärke ist als Logarithmus der Energie E des Signals S angegeben.

10

Als Lautstärke im Sinne der Erfindung wird jede physikalische Größe verstanden, die etwa proportional zur physikalischen Lautstärke ist, die in Dezibel gemessen wird. Hierzu proportionale Größen sind neben der Energie des Signals S die elektrischen Größen des in ein elektrisches Signal gewandelte

15 akustischen Signals, wie die Spannung oder der Strom.

20

Bei der Segmentierung des Signalabschnittes S werden Zeitpunkte t_1 , t_2 bestimmt, die jeweils eine Grenze zwischen einer Pause P und einem Wort W festlegen. Im dargestellten Ausführungsbeispiel ist zwischen dem Zeitpunkt 0 und t_1 bzw. nach dem Zeitpunkt t_2 eine Pause und zwischen den Zeitpunkten t_1 und t_2 stellt das Signal S ein Wort dar.

25

Im Schritt S_3 wird eine mittlere Ruhelautstärke S_i -Level bestimmt. Die mittlere Ruhelautstärke S_i -Level ist der zeitliche Mittelwert der Lautstärke von einem oder mehreren Pausenabschnitten P .

30

Im Schritt S_4 wird eine mittlere Wortlautstärke W_o -Level bestimmt. Die mittlere Wortlautstärke W_o -Level ist der zeitliche Mittelwert der Lautstärke von einem einzelnen Wortabschnitt W . D.h., daß für jedes einzelne Wort ein separater W_o -Level berechnet wird.

35

Im nachfolgenden Schritt S5 wird eine Differenz Δ zwischen der mittleren Wortlautstärke Wo-Level und der mittleren Ruhelautstärke Si-Level berechnet:

5
$$\Delta = \text{Wo-Level} - \text{Si-Level}$$

Danach wird im Schritt S6 abgefragt, ob die Differenz Δ kleiner als ein Schwellwert SW ist. Der Schwellwert SW stellt einen „Lautstärkenabstand“ dar (siehe auch Fig. 2).

10

Ergibt diese Abfrage, daß die Differenz Δ kleiner als der Schwellwert SW ist, so bedeutet dies, daß der Lautstärkenabstand zwischen der mittleren Wortlautstärke Wo-Level und der mittleren Ruhelautstärke Si-Level kleiner als der vorbestimmte

15

Schwellwert SW ist. Das Wort, dessen Lautstärkenabstand zwischen der mittleren Wortlautstärke Wo-Level und der mittleren Ruhelautstärke Si-Level kleiner als der vorbestimmte Schwellwert SW ist, wird als nicht korrekt erkannt beurteilt, da die Erfinder der vorliegenden Erfindung festgestellt ha-

20

ben, daß die Nebengeräusche in der Regel leiser als die auszuwertenden Wortsignale sind oder daß bei einem konstanten Störgeräusch (Rauschen in der Leitung, lautes Hintergrundgeräusch), bei welchen keine zufriedenstellende Spracherkennung möglich ist, der Lautstärkenabstand zwischen der mittleren

25

Wortlautstärke und der mittleren Ruhelautstärke sehr gering ist. Wird in beiden Fällen das erfaßte Signal in einen Text gewandelt, kommt es fast immer zu einer Fehlerkennung. Ergibt

30

die Abfrage im Schritt S6, daß die Differenz Δ kleiner als der Schwellwert SW ist, so wird der Programmablauf auf den Schritt S7 verzweigt, in dem eine Fehlerbehebung ausgeführt wird, die unten näher erläutert wird. Danach wird im Schritt S8 geprüft, ob ein weiteres Wort zu beurteilen ist. Falls das Ergebnis im Schritt S6 ist, daß die Differenz Δ größer als der Schwellwert SW ist, wird der Programmablauf direkt auf

35

eine Abfrage im Schritt S8 verzweigt.

Mit der Abfrage im Schritt S8 wird geprüft, ob noch ein weiteres Wort zu analysieren und zu bewerten ist, und falls das Ergebnis „ja“ ist, wird der Programmablauf zurück auf den Schritt S2 geführt, ansonsten wird das Programm mit dem Schritt S9 beendet.

Bei dem oben beschriebenen Ausführungsbeispiel werden die erfaßten Wörter einzeln analysiert, in Text gewandelt und bewertet. Dieses Verfahren wird als schritthaltende Erkennung bezeichnet. Hierbei ist es zweckmäßig, daß die Differenz Δ aus der mittleren Wortlautstärke W_o -Level eines Wortes W und der mittleren Ruhelautstärke S_i -Level der unmittelbar vorhergehenden Pause P gebildet wird. Es ist aber auch möglich, die mittlere Ruhelautstärke der auf das Wort W folgenden Pause oder eine über die vorhergehende oder die folgende Pause gemittelte Ruhelautstärke zu verwenden.

Anstelle einer schritthaltenden Erkennung kann auch eine mehrere Wörter zusammenfassende Erkennung verwendet werden. Hierbei ist es üblich jeweils einen vollständigen Satz als Signalabschnitt aufzunehmen und dann am Stück zu analysieren (satzweise Erkennung). Bei einer solchen satzweisen Erkennung kann die Ruhelautstärke über alle Pausen P gemittelt werden, wobei jedoch die mittlere Wortlautstärke für jedes Wort W einzeln zu ermitteln ist, damit die einzelnen Wörter als korrekt oder nicht korrekt erkannt beurteilt werden können.

Bei der Fehlerbehebung im Schritt S7 gibt es je nach Anwendungsfall unterschiedliche Varianten, die einzeln oder in Kombination eingesetzt werden können.

Nach der ersten Variante werden Wörter, die als nicht korrekt erkannt beurteilt worden sind, bei der Umwandlung in einen Text nicht berücksichtigt bzw. aus diesem entfernt.

Nach der zweiten Variante der Fehlerbehebung wird bei einem als nicht korrekt erkanntem Wort eine entsprechende Nachricht

an den Benutzer ausgegeben. Die Nachricht kann als akustische Nachricht (z.B.: „Das letzte Wort wurde nicht korrekt verstanden“) ausgegeben werden oder als bildliche Darstellung angezeigt werden. Ersteres ist für Spracherkennungssysteme ohne Anzeige, wie z.B. Telekommunikationsanlagen mit automatischer Spracherkennung zweckmäßig, und zweiteres kann z.B. bei Diktiersystemen sinnvoll sein. Bei Diktiersystemen kann als bildliche Darstellung ein vorbestimmtes Fehl-Zeichen an der entsprechenden Stelle im Text eingesetzt werden, mit dem der Benutzer aufgefordert wird, das Wort neu zu sprechen, das dann automatisch an die Stelle des Fehl-Zeichens in den Text eingesetzt wird. Will der Benutzer hier kein Wort einsetzen kann er eine entsprechende Löschfunktion zum Beseitigen des Fehl-Zeichens betätigen.

Nach einer dritten Variante der Fehlerbehebung kann der Benutzer durch eine entsprechende Nachricht aufgefordert werden, lauter zu sprechen, damit der geforderte Lautstärkenabstand erzielt wird. Hierdurch erfolgt eine Anpassung der Spracheingabe an die akustischen Bedingungen (Geräuschpegel beim Sprecher) bzw. den Bedingungen der Übertragung (Rauschen in der Leitung) des akustischen Signals. Falls eine wiederholte Aufforderung lauter zu sprechen zu keinem besseren Erkennungsergebnis führt, kann der Benutzer auch aufgefordert werden, andere akustische Bedingungen bzw. Übertragungsbedingungen zu schaffen, indem er z.B. aufgefordert wird, von einem anderen Telefonapparat zu telefonieren, falls er über ein Telefon mit dem Spracherkennungssystem verbunden ist.

Nach einer vierten Variante der Fehlerbehebung kann bei mehreren, aufeinanderfolgend als nicht korrekt erkannt bewerteten Wörtern dies als zu geringe Qualität der Spracheingabe beurteilt und dem Benutzer mit einer entsprechenden Nachricht ausgegeben werden.

Nach einer fünften Variante der Fehlerbehebung werden die Wörter sogenannter n-best-Listen einzeln bewertet. Oftmals

können einer Signalsequenz mehrere, ähnlich klingende Wörter zugeordnet werden. Diese Wörter bilden die n-best-Liste. Da sich die Grenzen zwischen den Pausen und dem jeweiligen Wort bei den einzelnen Wörtern der n-best-Liste unterscheiden, können für die einzelnen Wörter der n-best-Liste unterschiedliche mittlere Wortlautstärken und dementsprechend unterschiedliche Differenzen Δ ermittelt werden.

Die Auswahl des Wortes der n-best-Liste, das in den Text eingefügt wird, erfolgt nach an sich bekannten Match-Kriterien, wobei erfindungsgemäß die Differenz Δ als zusätzliches Match-Kriterium verwendet werden kann, wobei das Wort mit der größten Differenz Δ in den Text eingesetzt wird. Diese vierte Variante der Fehlerbehebung bildet einen selbständigen Erfindungsgedanken, der auch unabhängig von dem oben beschriebenen Verfahren bei der automatischen Auswertung von n-best-Listen eingesetzt werden kann.

Bei einer Ausführungsform der Erfindung ist der Schwellwert SW konstant.

Es ist jedoch auch möglich, den Schwellwert SW an die akustischen Bedingungen und an die Signalübertragungsbedingungen automatisch anzupassen. Bestehen hervorragende akustische Bedingungen und Signalübertragungsbedingungen, so werden in der Regel hohe Differenzen Δ erzielt, die wesentlich größer sind als konstante Schwellwerte, die für unterschiedliche Anwendungen und Bedingungen geeignet sein müssen. In einem solchen Fall ist es dann zweckmäßig, wenn der Schwellwert an die hohen Differenzen Δ angepaßt wird. So kann z.B. eine globale Differenz Δ_{gl} zwischen der mittleren Wortlautstärke mehrerer erfaßter Wörter und der mittleren Ruhelautstärke mehrerer erfaßter Pausen berechnet werden und diese globale Differenz Δ_{gl} direkt oder nach Abzug eines vorbestimmten konstanten Betrags als Schwellwert SW verwendet werden. Dies ist insbesondere in Kombination mit der ersten Variante der Fehlerbehebung von Vorteil, da hierdurch auch Nebengeräusche ausge-

filtert werden können, die nur geringfügig leiser als die mittlere Wortlautstärke sind. Dies hat zur Folge, daß bei einer Spracheingabe mit hoher Qualität die Schwelle unterhalb der die Signale als nicht korrekt erkannte Wörter beurteilt werden, höher gesetzt wird, als bei einer Spracheingabe mit schlechterer Qualität. Vorzugsweise ist eine untere Grenze für den Schwellwert vorgesehen, so daß dieser nicht auf Null vermindert werden kann.

- 10 Die Höhe des variablen Schwellwertes kann auch als Qualitätsfaktor der Spracheingabe beurteilt werden. Erreicht der variable Schwellwert seine untere Grenze, so bedeutet dies, daß die Qualität der Spracheingabe relativ schlecht ist, was dem Benutzer entsprechend mitgeteilt werden kann.

15

Bei der Berechnung der globalen Differenz werden vorzugsweise alle Pausen und Wörter berücksichtigt, die während eines Gespräches mit dem Spracherkennungssystem gesprochen werden.

- 20 In Fig.3 ist eine Ausführungsbeispiel einer Vorrichtung zum Erkennen von Sprache dargestellt. Diese Vorrichtung ist eine Telekommunikations-Anlage 1, die über eine Netzleitung 2 mit einem Telefonnetz verbunden ist. Die Telekommunikations-Anlage 1 weist eine Teilnehmer-Zugangssteuerung 3 auf, mit
25 welcher von außerhalb anrufende Fernsprechteilnehmer über einen internen Bus 4, einem Digital/Audio-Prozessor 5 und lokalen Telefonleitungen 6 mit einem Telefonendgerät 7 bzw. mit dem das Telefonendgerät benutzenden Benutzer verbunden werden können. Der interne Bus 4 ist mit einer Ansageeinheit 8 und
30 einer Spracheinheit 9 verbunden. Mit der Ansageeinheit 8 können auf den Bus 4 und damit auf die Telefonleitungen 2, 6 Ansagen eingebracht werden. Die Telekommunikations-Anlage wird von einem Mikroprozessor 10 gesteuert, der mit dem Digital/Audio-Prozessor 5, der Ansageeinheit 8 und der Spracheinheit 9 verbunden ist.
35

11

Die Spracheinheit 9 ist aus einem Sprachanalysemodul 11, einem Lautstärkenmeßgerät 12 und einer Sprachsteuerung 13 ausgebildet.

- 5 Das Sprachanalysemodul 11 führt die Analyse des Sprachsignals durch, wobei das Sprachsignal in Pausen und Wörter segmentiert wird und die Wörter in Text gewandelt werden. Das Sprachanalysemodul leitet an das Lautstärkenmeßgerät 12 die einzelnen Teile (Wörter W und Pausen P) des Sprachsignals S
- 10 und an die Sprachsteuerung 13 den konvertierten Text weiter. Das Lautstärkenmeßgerät ermittelt die mittlere Lautstärke (Wo-Level, Si-Level) der einzelnen Teile des Sprachsignals und gibt die entsprechenden Werte an die Sprachsteuerung 13 weiter. In der Sprachsteuerung 13 wird geprüft, ob die ein-
- 15 zeln Wörter korrekt erkannt worden sind (Schritt S6 in Figur 1), wobei ggfs. die Ausfilterung nicht korrekt erkannter Worte in der Sprachsteuerung 13 vorgenommen wird (erste Variante der Fehlerbehebung).
- 20 Der gefilterte oder ungefilterte Text wird von der Sprachsteuerung 13 mit weiteren zur Fehlerbehebung notwendigen Daten an den Mikroprozessor 10 weitergegeben, der den empfangenen Text und die korrespondierenden Daten auswertet.
- 25 Eine Funktion des Mikroprozessors 10 ist, die eingehenden Anrufe automatisch mit den jeweiligen Telefonendgeräten 7 zu verbinden. Die erfolgt durch Auswertung des vom Sprachsteuerung 13 empfangenen Textes und durch entsprechendes Freischalten des jeweiligen Ausgangs des Digital/Audio-Prozessors
- 30 5.

Kann der empfangene Text nicht ausgewertet werden oder ist eine Fehlerbehandlung mit Ansage (zweite, dritte oder vierte Variante) notwendig, so wird die Ansageeinheit 8 vom Mikro-

35 prozessor zur Durchführung der entsprechenden Ansage gesteuert.

In die erfindungsgemäße Telekommunikations-Anlage ist somit eine automatische Vermittlung integriert, die die eingehenden Telefongespräche selbsttätig an die jeweiligen Telefonendgeräte weiterleiten kann.

5

Mit der erfindungsgemäßen Telekommunikations-Anlage 1 ist es auch möglich, daß die Benutzer der Telefonendgeräte 7 die Telekommunikations-Anlage 1 mit ihrer Stimme steuern und bspw. die zu wählende Nummer sprechen, anstelle sie auf den Tasten zu tippen.

10

All diese Funktionen setzen eine möglichst fehlerfreie Spracherkennung voraus. Durch die Erfindung können Fehler durch Nebengeräusche, sei es durch ein Sprachsignal im Hintergrund oder durch ein kein Sprachsignal darstellendes Geräusch, wesentlich besser und auf einfachere Art und Weise als bei herkömmlichen Spracherkennungssystemen vermieden werden.

15

Patentansprüche

1. Verfahren zum Erkennen von Sprache,

- 5 a) bei dem anhand von Wortgrenzen Wörter und Pausen in der Sprache bestimmt werden;
- b) bei dem eine mittlere Ruhelautstärke (Si-Level) während der Pausen ermittelt wird;
- c) bei dem eine mittlere Wortlautstärke (Wo-Level) für die Wörter ermittelt wird;
- 10 d) bei dem eine Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) bestimmt wird;
- e) bei dem Sprache erkannt wird, falls die Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und
- 15 der mittleren Ruhelautstärke (Si-Level) größer als ein vorbestimmter Schwellwert (S) ist;
- f) bei dem ansonsten keine Erkennung der Sprache durchgeführt wird.

20 2. Verfahren nach Anspruch 1,

bei dem die mittlere Ruhelautstärke und die mittlere Wortlautstärke als Logarithmus über die erfaßte Energie gemessen wird.

25 3. Verfahren nach Anspruch 1 oder 2,

bei dem eine globale Differenz zwischen der mittleren Wortlautstärke mehrerer segmentierter Wörter und der mittleren Ruhelautstärke mehrerer segmentierter Pausen berechnet wird und anhand der globalen Differenz der

30 Schwellwert bestimmt wird.

4. Verfahren nach Anspruch 3,

bei dem der Schwellwert der globalen Differenz gleichgesetzt wird.

35 5. Verfahren nach Anspruch 3,

bei dem die globale Differenz um einen vorbestimmten,

konstanten Betrag vermindert und der sich hieraus ergebende Lautstärkebetrag als Schwellwert verwendet wird.

- 5 6. Verfahren nach Anspruch 1 oder 2,
bei dem ein konstanter Schwellwert verwendet wird.
7. Verfahren nach einem der Ansprüche 1 bis 6,
bei dem ein Wort, für das keine Erkennung der Sprache durchgeführt wird, nicht weiter berücksichtigt wird.
- 10 8. Verfahren nach einem der Ansprüche 1 bis 7,
bei dem, falls keine Erkennung der Sprache durchgeführt wird, eine Nachricht an einen Benutzer ausgegeben wird.
- 15 9. Verfahren nach Anspruch 8,
bei dem der Benutzer mit der Nachricht aufgefordert wird, lauter zu sprechen und/oder das nicht korrekt erkannte Wort zu wiederholen.
- 20 10. Verfahren nach Anspruch 9,
bei dem anhand der Nachricht der Benutzer aufgefordert wird, lauter zu sprechen, damit ein ausreichender Abstand zwischen der mittleren Wortlautstärke zur mittleren Ruhelautstärke erzielt wird.
- 25 11. Verfahren nach einem der vorhergehenden Ansprüche,
bei dem die mittlere Ruhelautstärke jeweils für eine einzelne Pause ermittelt wird und die Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) des gesprochenen Wortes und der mittleren Ruhelautstärke (Si-Level) der unmittelbar vorausgehenden Pause oder der unmittelbar nachfolgenden Pause bestimmt wird.
- 30 12. Verfahren nach einem der vorhergehenden Ansprüche,
bei dem die mittlere Ruhelautstärke über mehrere aufeinanderfolgende Pausen gemittelt wird und diese gemittelte
- 35

Ruhelautstärke bei der Bestimmung der Differenz (Δ) verwendet wird.

13. Verfahren nach einem der vorhergehenden Ansprüche,
5 bei dem eine n-best-Liste erstellt wird, und jedem Wort der n-best-Liste eine Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) der einzelnen gesprochenen Wörter und der mittleren Ruhelautstärke (Si-Level) zugeordnet wird, und das in den Text aus der n-best-Liste
10 einzusetzende Wort nach Maßgabe dieser Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) der einzelnen gesprochenen Wörter und der mittleren Ruhelautstärke (Si-Level) bestimmt wird.
- 15 14. Anordnung zum Erkennen von Sprache mit eineressoreinheit, die derart eingerichtet ist, daß
- a) anhand von Wortgrenzen Wörter und Pausen in der Sprache bestimmbar sind;
 - 20 b) eine mittlere Ruhelautstärke (Si-Level) während der Pausen ermittelbar ist;
 - c) eine mittlere Wortlautstärke (Wo-Level) für die Wörter ermittelbar ist;
 - 25 d) eine Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) bestimmbar ist;
 - e) Sprache erkannt wird, falls die Differenz (Δ) zwischen der mittleren Wortlautstärke (Wo-Level) und der mittleren Ruhelautstärke (Si-Level) größer als ein vorbestimmter Schwellwert (S) ist;
 - 30 f) ansonsten keine Erkennung der Sprache durchgeführt wird.

Zusammenfassung**Verfahren und Anordnung zum Erkennen von Sprache**

- 5 Erfindungsgemäß wird ein Lautstärkenabstand zwischen den erkannten Wörtern und den dazwischen liegenden Pausen ermittelt. Ist der Lautstärkenabstand eines Wortes kleiner als ein vorbestimmter Schwellwert, so wird das Wort als nicht korrekt erkannt beurteilt. Hierdurch werden durch Nebengeräusche verursachte Fehler auf eine einfache Art und Weise vermieden.
- 10

Figur 2

FIG 1




FIG 2




FIG 3

